

# Konstgjorda blodcellsbilder ger bättre klassificering

De bästa bildklassificeringsmodellerna, så kallade deep learning-modeller, är bra men i stort behov av data för att prestera. För att förbättra sådana modellers prestation kan man utöka redan existerande dataset som används för träning av dessa modeller. Vi har använt oss av en modell som kallas GAN för att producera konstgjord träningsdata och visat att det kan förbättra en blodcellsklassificerare.

De senaste årens framsteg inom AI och Machine Learning har möjliggjort automatiseringar av uppgifter inom en rad olika områden, inte minst inom den medicinska världen. Uppgifter som tidigare utfördes för hand med mikroskop kan idag utföras av maskiner på en bråkdel av tiden, vilket tillåter läkare att fokusera på analys och beslutsfattande snarare än det mekaniska insamlandet av data. Lundaföretaget CellaVisions produkter erbjuder hematologiska laboratorier (läkare som specialiserar sig på blod) en lösning för att automatiskt utföra så kallade blodcells-differentialer. Blodcells-differentialer går kortfattat ut på att bestämma förhållandet mellan antalet vita blodkroppar av olika sorter och därav dra medicinska slutsatser om patientens tillstånd.

Cellavisions produkter fotograferar blodprov och låter en dator lokalisera de vita blodkropparna. Därefter avgör datorn vilken sorts vit blodkropp det rör sig om. Denna klassificering sker med hjälp av Deep Learning-metoder, som är avancerade matematiska modeller med flera miljoner parameterar. För att en Deep Learning-modell ska kunna klassificera de vita blodkropparna måste den först tränas. Träningen sker genom ett slags frågesport, där modellen får se bilder och yttra sig om vilka klasser bilderna tillhör. Modellens parameterar uppdateras sedan baserat på hur nära facit den kom och frågesporten upprepas. Genom att träna modellen på detta vis förstår den successivt vad som skiljer klasserna åt och lär sig leta efter utmärkande drag i cellbilderna.

Deep Learning-modeller för bildklassificering kan ofta ge spektakulära resultat, men för att modellerna ska fungera så krävs väldigt mycket data under träningsprocessen, data som i många fall är en dyr och svåråtkomlig resurs. I brist på data försöker deep learning-utövare utöka datasetet genom att till exempel vända upp och ner på bilder eller spegelvända dem, en så kallad *augmentering* av datasetet. Informationen som sådana tillskott i datasetet tillför är emellertid begränsad. Ett alternativ är att på konstgjord väg försöka skapa helt ny data. I detta arbete har vi utvärderat en metod för att skapa cellbilder, nämligen Generative Adversarial Networks (GAN), som också är en deep learning-modell. GAN-modellen består egentligen av två modeller, en *generator* och en *diskriminator*. Generatoren har som uppgift att generera bilder som ska se så verklighetstrogn ut som möjligt, medan diskriminatoren ska försöka avgöra om bilderna är äkta eller genererade. Generatoren uppdateras baserat på hur bra den lyckas lura diskriminatoren. Effekten är ett slags tävling mellan generatoren och diskriminatoren som driver generatoren till att producera bättre och bättre bilder.

Genom att träna en klassificeringsmodell med hjälp av ett dataset utökat med de av generatoren producerade "falska" cellbilderna lyckades vi förbättra klassificeringsresultatet i jämförelse med en modell tränad på det ursprungliga datasetet.

**Oskar Klang & Martin Carlberg**